

DOI: 10.13718/j.cnki.xdzk.2020.12.005

基于多源遥感协同反演的 区域性土壤含水率动态研究

孙宇乐, 屈忠义, 刘全明, 王丽萍

内蒙古农业大学 水利与土木建筑工程学院, 呼和浩特 010018

摘要: 为进一步推动多源遥感技术在农业生产与管理中的应用, 以内蒙古河套灌区五原县 3 500 hm² 研究区为实验对象, 对实验区进行实地取样化验, 获取并处理了多种遥感影像, 综合研究光学影像地表反射率及雷达影像后向散射系数对土壤含水率的响应特征。对遥感影像数据进行各种数学变换, 求出其与土壤含水率的相关性强弱; 利用 SPSS 与 MATLAB 对数据进行回归分析, 采用多元线性回归、最小二乘回归、神经网络回归等不同的回归方法进行分析, 得出相对应的回归模型方程, 建立了多数据源含水率反演模型。ALOS, 北京二号和 Landsat 影像协同反演土壤含水率神经网络的拟合值达到 0.892, R² 值达到 0.796, 模型的稳定性和预测精度较好, 可知融合多源遥感数据的神经网络模型可快速精准监测土壤含水率的动态变化规律, 为灌区农业生产及土壤盐碱化防治提供基础信息指导。

关键词: 遥感反演; 相关性分析; 回归分析; 神经网络; 水分反演模型

中图分类号: S152.7; P628⁺.2

文献标志码: A

文章编号: 1673-9868(2020)12-0046-08

土壤含水率是一个重要的土壤物理参数, 它是生态系统水循环、植物生长、土壤承载能力等研究领域必不可少的基本参数^[1]。地表土壤含水率影响着地表与大气的水分和能量交换^[2], 是农作物生长发育的基本条件, 是保证植被健康生长的重要因素^[3]。因此, 土壤含水率是评价土地资源的重要指标, 是精准农业中极为关键的参数, 土壤含水率的监测有着十分重要的意义^[4-5]。传统的土壤含水率测定方法一般都依赖于密集的野外采样等, 这些采样方法成本偏高、调查周期较长、且容易受制于采样时间和采样范围^[6]。另外, 这些方法以点测量为基础, 代表性差, 体现区域土壤含水率空间变异性尤为困难^[7], 难以实现大尺度土壤含水率变化的实时监测和快速更新^[8]。遥感技术以其高效、快速的优势已经广泛应用到土壤属性监测中^[9]。利用遥感技术进行大面积、实时的土壤信息提取, 使区域尺度土壤状况的时空动态监测成为现实^[10]。

20 世纪 80 年代末期, 日本采用 NOAA 卫星资料的 CCT 磁带, 结合近地层小气候及地下热流量观测, 以中国东北部的吉林省为中心进行了区域土壤水分调查, 取得了良好的效果^[11]。墨西哥水利资源部与美国 NASA 合作, 利用遥感资料在不同土壤类型区进行了水资源的调查工作, 评价了土壤的干旱程度, 并编制了相应的图件^[12]。

国内学者也对此做了大量研究。蔡亮红等^[13]利用小波变换对土壤光谱进行了 8 层分解, 分别对分解后的特征光谱进行了 9 种数学运算建立与土壤水分的回归模型, 为反射率法反演土壤水分提供了新思路。武

收稿日期: 2019-10-31

基金项目: 国家重大科技专项(2016YFC0501301); 国家自然科学基金项目(51569018); 内蒙古农业大学“双一流”学科创新团队建设人才培养项目(NDSC2018-10)。

作者简介: 孙宇乐(1993-), 男, 硕士研究生, 主要从事盐碱地水盐运移规律的研究。

通信作者: 刘全明, 博士, 副教授。

晋雯等^[14]针对不同植被条件下的土壤水分监测方法进行了比较;刘焕军等^[15]则针对性研究了黑土的土壤水分的高光谱模型.杨曦光等^[16]利用便携式地物光谱仪采集不同水分梯度土壤样品的反射光谱,通过试验光谱数据建立了一个基于指数函数的土壤含水率遥感反演模型.王学等^[17]使用 Dobson 模型建立了一个较为完整的土壤介电特性研究体系,为微波遥感监测土壤水分奠定了基础.张智韬等^[18]使用归一化土壤湿度指数模型监测土壤含水率.刘全明等^[19]采用 BP 神经网络技术对内蒙古河套灌区内 1 个试验区春季水盐网格采样数据进行了水盐估计,证明 BP 神经网络技术可以用于二维区域水盐监测.丁建丽等^[20]以 MODIS 与 Landsat TM 数据为数据源,进行干旱区表层土壤水分的模拟.徐星等^[21]研究发现经过遗传算法优化过的 Elman 神经网络在训练过程中收敛性更好,应用中泛化性更强、稳定性更高,可有效判别水化指标.这些土壤水分的反演方法在区域研究中表现良好但并不意味着具有普适性,虽然理论基础相同,但在实际应用中表现各异,因此土壤水分的遥感反演方法始终是研究热点.

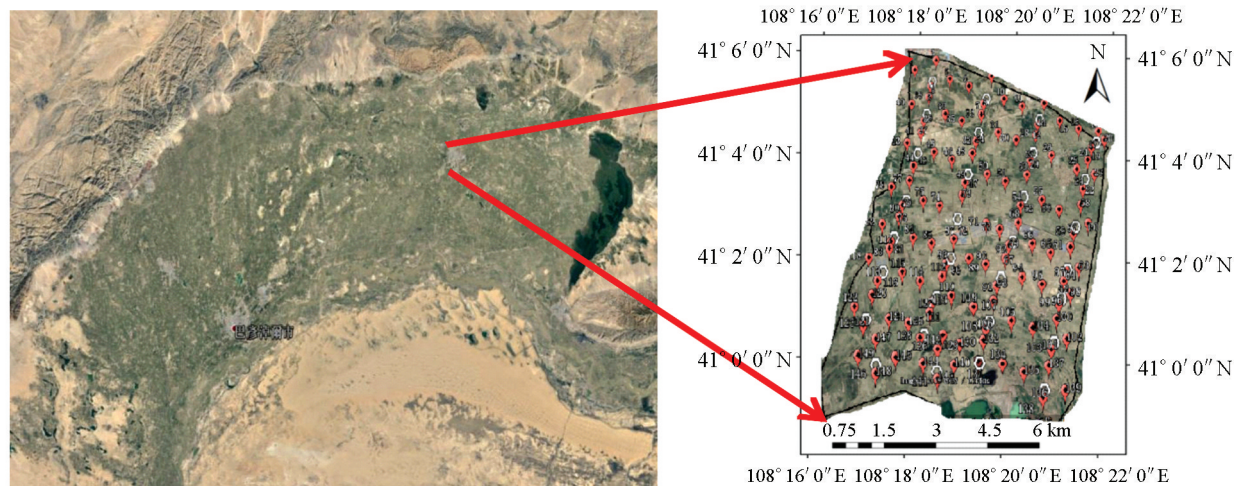
鉴于此,本研究针对内蒙古五原县 3 500 hm² 研究区利用多源遥感数据对土壤含水率进行协同反演,并引入不同的相关性分析及回归性分析计算方法,从而将雷达后向散射系数、光谱地表反射率及其变换值等参数转换为土壤含水率,以提高土壤含水率监测的精度与广适性.

1 材料与方 法

1.1 研究区概况

河套灌区位于中国西部,是黄河上中游内蒙古地区黄河北岸的冲积平原,在位置上为北纬 40°19′—41°18′,东经 106°30′—109°19′之间,属于内蒙古自治区西部的巴彦淖尔市南部.河套灌区东西长 250 余 km,灌区内南北宽 40~60 km,灌区总面积约为 119 万 hm²,其中灌溉面积超过 66%,年均引黄河水量近 50 亿 m³,排水量仅约 4 亿 m³(数据来源于 2015 年内蒙古自治区巴彦淖尔市水务局《水资源综合规划报告》).

本研究所选择的试验区是河套灌区内五原县 3 500 hm² 研究区(图 1).五原县地处内蒙古河套平原腹地,县域南临黄河(属黄河最北端),北有阴山横亘,东临鹿城包头,西与临河市接壤,是一颗有着两千多年文明历史的塞上明珠.地理坐标为东经 107°35′70″—108°37′50″,北纬 40°46′30″—41°16′45″.县境东西最长 82 km,均长 62.3 km,南北最宽 55.5 km,均宽 40 km,总面积 2 492.9 km²,占河套灌区总面积的 1/4.



(a) 河套灌区

(b) 五原县 3 500 hm² 研究区取样示意图

图 1 研究区位置图

1.2 采样点布置及数据收集处理

本研究于 2018 年 9 月 25—28 日对五原县 3 500 hm² 研究区进行了覆盖全研究区的土壤采样与调研工作,样点布设综合考虑了不同土地利用、种植方式、灌溉方式、地下水位等情况,取样点总体以网格状覆盖整个研究区,总计获取 149 个土壤取样点.本次取样处于秋收后、秋浇前,土壤水分尚未受灌溉影响;同

时,该时期干旱少雨,且由于作物刚刚收获,土壤水分尚未进行长时间的裸露蒸发.因此,此时的土壤含水率的样本信息可更真实地反映研究区的土壤湿润程度及其空间差异.

区域取样时用 GPS 做导航,首先找到某一点所在的田块,后在田块中央取样,并记录取样点的位置以方便下次在其周围取样.综合考虑作物根系深度及土壤水分下渗深度变化趋势,取样深度设为 60 cm.取样时除去采样点表面植被,按 0~20 cm,21~40 cm,41~60 cm 依次进行分层取样,在距采样点 5 m 的两侧位置以同样的方式进行重复采样 2 次,用于精度校验.土壤含水率采用烘干法测定.

本研究采用同时期 Landsat-8 OLI_TIRS(30 m 分辨率)及北京二号(3.2 m 分辨率)光学影像数据和 ALOS-2 雷达影像进行多源遥感数据协同反演.

在获取遥感影像时,由于遥感器在观测过程中受到光照影响、电磁波在大气中传输时受到大气作用等多种因素的影响,遥感影像会出现一定程度的辐射和几何失真现象.在使用光学遥感影像之前需要进行图像裁剪、辐射校正和几何校正等图像预处理措施.本研究使用 ENVI 5.3 软件进行图像预处理,得到光学遥感影像的地表反射率数据.雷达影像处理使用 ENVI 5.3 软件的 SAR Scape 模块对原始 SLC 影像进行多视、滤波、地理编码和辐射定标等处理,将实地取样时获取的取样点坐标使用 Arcgis 软件转换为取样点 shp 文件,对影像进行几何配准后,得到 HH(水平极化方式发射,水平极化方式接收),HV(水平极化方式发射,垂直极化方式接收)2 种极化方式的后向散射系数.

1.3 相关性分析方法

皮尔逊相关性常用定量描述两个变量之间的线性关系和密切程度.皮尔逊线性相关性分析只能用于两个变量之间的分析,而且要求两个变量都呈正态分布,且为随机变量,并不是人为控制的变量.

双尾显著性检验是一种假设检验,其检验统计量的异常取值有两个方向,即概率分布曲线的左侧(对应于过小的值)和右侧(对应于过大的值).一般情况下,概率分布函数曲线两侧尾端的小概率事件都要考虑(即双侧检验).如果事先有把握确定其中的一侧不可能取值,则仅需对另一侧的小概率事件进行检验即可(单侧检验).一般情况下,认为相关性在小于 0.05 的范围内,这个相关显著会犯错误的可能为小于 5%,也就是说有 95%的把握认为相关的确存在.

1.4 回归性分析方法

回归性分析是对两种或两种以上的变量确定一种关系式,用来研究因变量和自变量之间的关系.

1.4.1 线性回归

在统计学分析中,线性回归是对因变量和自变量的关系进行建模的一个过程.只有一个因变量和自变量且他们之间保持线性关系的称为一元线性回归分析.若有多个因变量和自变量并且关系也为线性关系的称为多元线性回归分析.通常在线性回归中要利用预测函数来对相关数据进行建模.同时也可以推算一些未知的模型参数.预测一个 y 值,给定一些变量 X_1, X_2, \dots, X_p 和一个变量 y ,预测 y 和 X_1, X_2, \dots, X_p 可能有关系,通过软件分析出他们之间的关系.

1.4.2 BP 神经网络

BP(Error Back Propagation)神经网络是 1986 年由 Rumelhart 和 McClelland 为首的科研小组提出,BP 神经网络是一种按误差逆传播算法训练的多层前馈网络,是目前应用最广泛的神经网络模型之一.BP 神经网络能学习和存贮大量的输入—输出模式映射关系,而无需事前揭示描述这种映射关系的数学方程.它的学习规则是使用最速下降法,通过反向传播来不断调整网络的权值和阈值,使网络的误差平方和最小.

2 数据分析

2.1 相关性分析

本研究采用 SPSS 软件对原始数据做了相关性分析.本次分析中采用皮尔逊相关系数和双尾检验结合对比衡量两者之间的相关性.

ALOS 雷达影像从极化方式和它们的变化来分析,LN(HH)/LN(HV)与含水率的相关性相对最高.而通过 ALOS 影像获取的数据与土壤含水率的相关性整体较弱,效果不佳.因此根据相关性分析结果,选取相关性相对大的 HH,HV 和 LN(HH)/LN(HV)进行线性回归分析.

北京二号光学影像地表反射率各数学形式变换与土壤含水率的相关性分析中, 红波及其各种数学形式变换与影像地表反射率的相关性最高. 取北京二号影像地表反射率数据与土壤含水率相关性较大的变换方式进行逐步线性回归, 建立回归方程, 分析对比后选出: 与土层(0~20 cm)含水率做相关性分析, 相关性显著的变换形式为红波、绿波倒数和蓝波倒数; 与土层(21~40 cm)含水率做相关性分析, 相关性显著的变换形式为红波、绿波和蓝波对数的倒数; 与土层(41~60 cm)含水率做相关性分析, 相关性显著的变换形式为红波倒数、绿波倒数和蓝波倒数.

Landsat 光学影像中, 与土层(0~20 cm)含水率做相关性分析, 相关性显著的变换形式为红波对数、绿波和蓝波对数的倒数; 与土层(21~40 cm)含水率做相关性分析, 相关性显著的变换形式为红波倒数、绿波和蓝波对数的倒数; 与土层(41~60 cm)含水率做相关性分析, 相关性显著的变换形式为红波原数, 绿波倒数和蓝波对数的倒数.

2.2 回归性分析

2.2.1 多源数据协同反演线性回归

综合 ALOS, 北京二号和 Landsat 影像各组与土壤含水率相关性显著的数据组进行多元回归分析, 结果见表 1.

表 1 ALOS, 北京二号和 Landsat 影像协同反演土壤含水率线性回归分析结果

影像	含水层数	公 式	R^2	RMSE	显著性
ALOS, 北京 二号和 Landsat 影像协同反演	0~20 cm	$S_{20} = -1.753 + 0.526HH - 0.686HV - 0.108(\text{LN}(\text{HH})/\text{LN}(\text{HV})) - 7.229X_2 + 4.911X_4 + 0.021X_7 - 2.970X_8 + 0.249X_9 - 0.015X_{14} - 0.090X_{15}$	0.425	0.049	0.000
	21~40 cm	$S_{40} = 2.709 + 1.259HH - 0.528HV - 0.019(\text{LN}(\text{HH})/\text{LN}(\text{HV})) - 0.009X_3 + 1.816X_4 - 0.017X_7 - 0.288X_9 - 0.464X_{10} - 2.342X_{16}$	0.153	0.003	0.720
	41~60 cm	$S_{60} = -63.630 + 1.265HH + 0.632HV - 0.249(\text{LN}(\text{HH})/\text{LN}(\text{HV})) + 22.479X_1 - 1.215X_5 - 4.323X_8 + 0.015X_{13} - 0.016X_{14} - 0.080X_{15}$	0.272	0.038	0.064


注: X_1 为 Landsat 影像中的红波, X_2 为 Landsat 影像中的红波对数, X_3 为 Landsat 影像中的红波倒数, X_4 为 Landsat 影像中的绿波对数, X_5 为 Landsat 影像中的绿波倒数, X_6 为 Landsat 影像中的绿波对数的倒数, X_7 为 Landsat 影像中的蓝波倒数, X_8 为 Landsat 影像中的蓝波对数的倒数, X_9 为北京二号影像中的红波, X_{10} 为北京二号中的绿波, X_{11} 为北京二号影像中的蓝波, X_{12} 为北京二号影像中的绿波对数, X_{13} 为北京二号影像中的红波倒数, X_{14} 为北京二号影像中的绿波倒数, X_{15} 为北京二号影像中蓝波倒数, X_{16} 为北京二号影像中蓝波对数的倒数.

在对各个土层的含水率与影像数据的各个变换形式进行相关性分析后, 将各变换形式中与对应土层的含水率数值相关性较大的遥感数据和相应土壤含水率数据分别作为预测土壤含水率的自变量和因变量, 根据线性回归模型得出表 1 所示的分析结果. 3 层土壤含水率的线性回归模型拟合系数 R^2 为 0.153~0.425, 均方误差(RMSE)为 0.003~0.049. 多源遥感数据回归模型具有一定的模拟性能, 但拟合精度和拟合效果较差.

2.2.2 BP 神经网络模型模拟


以 ALOS 雷达影像的后向散射系数 HH, HV 及 $\text{LN}(\text{HH})/\text{LN}(\text{HV})$ 值, 北京二号光学影像中的红波、绿波、蓝波反射率的对数值, Landsat 光学影像中的红波、绿波、蓝波反射率对数的倒数值作为 BP 神经网络的 9 个输入因子, 输出对应分层土壤含水率数值, 使用 Matlab 自带神经网络工具箱完成 BP 神经网络计算与模拟, 拟合效果见图 2.

通过神经网络拟合分析图能直观地看出在 3 个影像神经网络拟合分析后, 其中土壤层数(0~20 cm)和(41~60 cm)拟合值已经达到 0.8 以上, 拟合反演值接近理想值, 拟合效果达到了最佳, 体现了多源遥感的优越性.



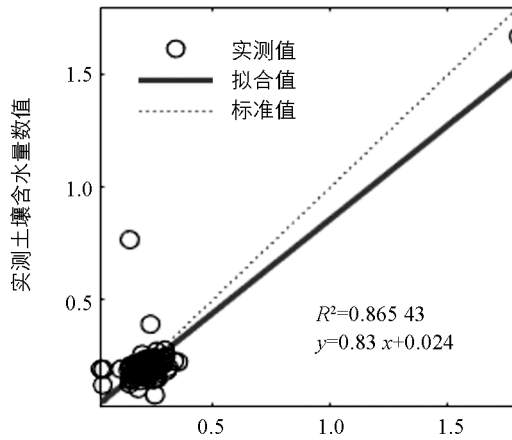
神经网络拟合土壤含水率反演值

(a) 0~20 cm神经网络拟合反演值



神经网络拟合土壤含水率反演值

(b) 21~40 cm神经网络拟合反演值



神经网络拟合土壤含水率反演值

(c) 41~60 cm神经网络拟合反演值

图 2 ALOS,北京二号和 Landsat 影像协同反演土壤含水率神经网络拟合分析

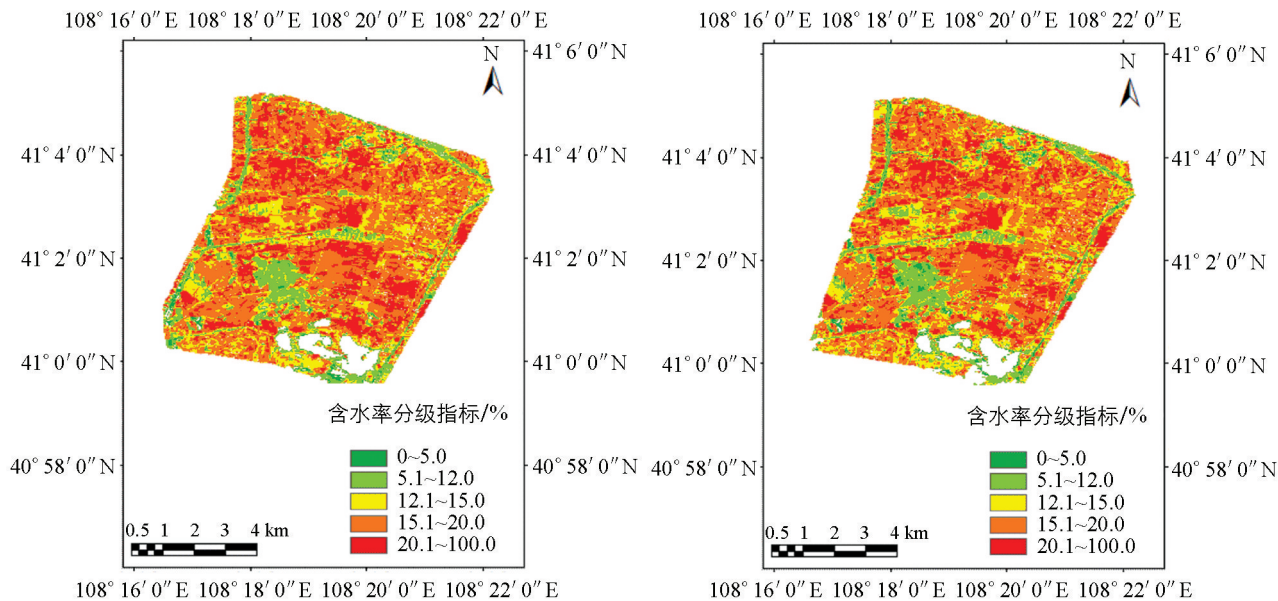
表 2 反映出线性回归拟合系数 R^2 最高达到 0.425, 最低的拟合系数仅为 0.017, 而神经网络的拟合系数 R^2 均高于线性回归, 最高的达到 0.796. 可知, 从单一 ALOS 雷达影像、ALOS 雷达影像协同北京二号光学影像到 ALOS 雷达影像、北京二号光学影像和 Landsat 光学影像三源协同, 从单源、双源到三源, 其模拟精度逐步提高, 主要原因一是多源数据融合微波雷达与光学遥感, 模型精度较单源遥感数据普遍提高, 其集合了微波后向散射特性与光学特征波段多因子建模分析, 拟合效果达到最佳; 二是神经网络具有高度非线性函数逼近优点, 优于普通多元线性回归, 适宜于土壤水分复杂性模拟问题.

表 2 线性回归和神经网络分析结果对比

影像	R^2	土壤层数 (0~20 cm)	土壤层数 (21~40 cm)	土壤层数 (41~60 cm)
ALOS	线性回归	0.038	0.030	0.017
	神经网络	0.109	0.131	0.082
ALOS,北京二号	线性回归	0.095	0.062	0.066
	神经网络	0.230	0.148	0.103
ALOS,北京二号,Landsat	线性回归	0.425	0.153	0.272
	神经网络	0.796	0.308	0.748

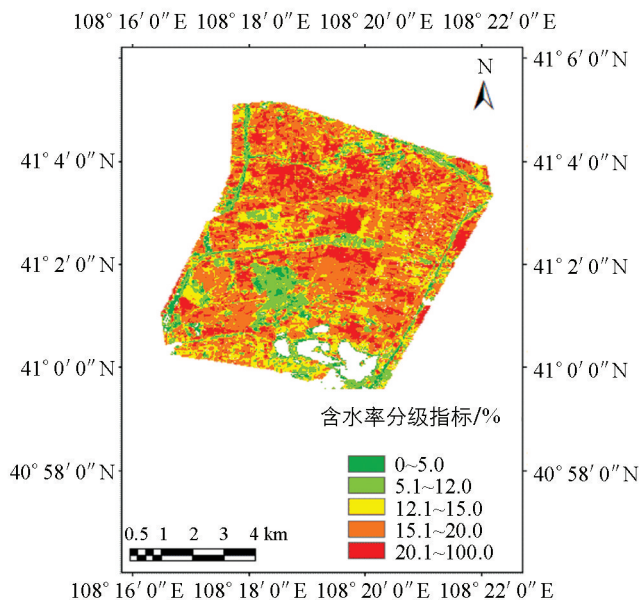
2.3 ALOS, 北京二号和 Landsat 影像协同反演图

图 3 为 ALOS 雷达影像联合北京二号和 Landsat 光学影像协同反演的研究区内土壤含水率的反演图。从反演图不难看出, 3 种影像协同反演可以将五原县整个区域的含水率较为清晰地表现出来。大体上看, 研究区土壤湿润情况总体表现为含水率较高, 随着取样层数的递增, 含水率逐步提高, 这可能是研究区内土壤盐碱化程度较为严重的一个主要原因, 在今后的土地治理及农业生产活动中要着力降低土壤的含水率, 才能达到有效改善土地质量及提高农作物产量的目的。土壤含水率分级指标见表 3。



(a) 0~20 cm 土壤含水率反演预测结果

(b) 21~40 cm 土壤含水率反演预测结果



(c) 41~60 cm 土壤含水率反演预测结果

图 3 土壤含水率反演预测结果

表 3 土壤含水率分级指标

干旱程度	实际土色	土壤水分	含水率/%
偏湿	暗黑	湿	>20.0%
适宜	褐色	潮湿	15.1%~20.0%
轻旱	黄色	湿润	12.1%~15.0%
中旱	浅灰	黄半干	5.1%~12.0%
重旱	灰白	干	≤5.0%

3 结 论

1) 通过不同数学形式变换后的光学影像地表反射率数据和雷达影像后向散射系数数据较数据原形式相比,与土壤含水率的相关关系得以提升,更具有数据代表性.在各种数学变化中发现倒数变化后的数据具有更好的数据相关性.

2) 3种影像协同反演会使各个土层含水率所对应的 R^2 值均有所提高,多源数据融合微波雷达与光学遥感,模型精度较单源遥感数据普遍提高,其集合了微波后向散射特性与光学特征波段多因子建模分析,拟合效果达到最佳,体现了多源遥感的互补性,减少了单一遥感的诸多不确定性,同时,神经网络具有高度非线性函数逼近优点,优于普通多元线性回归,适宜于土壤水分复杂性模拟问题.

3) ALOS,北京二号和 Landsat 影像协同反演土壤含水率神经网络的拟合值达到 0.892, R^2 值达到 0.796,模型的稳定性和预测精度较好.说明融合多源光学遥感数据地表反射率与雷达后向散射系数而构建的多源遥感数据源神经网络模型在反演地表土壤含水率时具有明显的优势.

参考文献:

- [1] 李笑吟,毕华兴,刁锐民,等. TRIME-TDR 土壤水分测定系统的原理及其在黄土高原土壤水分监测中的应用 [J]. 中国水土保持科学, 2005, 3(1): 112-115.
- [2] 李明泽,高元科,邸雪颖,等. 基于微波遥感技术探测森林地表土壤含水率 [J]. 应用生态学报, 2016, 27(3): 785-793.
- [3] 刘伟东,FRÉDÉRIC BARET,张 兵,等. 高光谱遥感土壤湿度信息提取研究 [J]. 土壤学报, 2004, 41(5): 700-706.
- [4] 裴承忠,彭 翔,曾文治,等. 盐渍条件下土壤含水率高光谱反演研究 [J]. 中国农村水利水电, 2016(8): 73-75,82.
- [5] 王全九,王文焰,汪志荣,等. 盐碱地膜下滴灌技术参数的确定 [J]. 农业工程学报, 2001, 17(2): 47-50.
- [6] NANNI M R, DEMATTÉ J A M. Spectral Reflectance Methodology in Comparison to Traditional Soil Analysis [J]. Soil Science Society of America Journal, 2006, 70(2): 393-407.
- [7] D'URSO G, MINACAPILLI M. A Semi-empirical Approach for Surface Soil Water Content Estimation from Radar Data without A-priori Information on Surface Roughness [J]. Journal of Hydrology, 2006, 321(1-4): 297-310.
- [8] WANG Q, LI P H, PU Z, et al. Calibration and Validation of Salt-resistant Hyperspectral Indices for Estimating Soil Moisture in Arid Land [J]. Journal of Hydrology, 2011, 408(3-4): 276-285.
- [9] YANG X G, YU Y. Estimating Soil Salinity under Various Moisture Conditions: an Experimental Study [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(5): 2525-2533.
- [10] HASSAN-ESFAHANI L, TORRES-RUA A, JENSEN A, et al. Assessment of Surface Soil Moisture Using High-Resolution Multi-Spectral Imagery and Artificial Neural Networks [J]. Remote Sensing, 2015, 7(3): 2627-2646.
- [11] 宇都宫阳二郎,赵华昌,华润葵,等. 利用 NOAA 卫星遥感编制中国东北部土壤水分分布图 [J]. 遥感技术动态, 1990 (4): 27-30.
- [12] 陈述彭,赵英时. 遥感地学分析 [M]. 北京: 测绘出版社, 1990.
- [13] 蔡亮红,丁建丽. 基于高光谱多尺度分解的土壤含水量反演 [J]. 激光与光电子学进展, 2018, 55(1): 400-409.
- [14] 武晋雯,孙龙彧,张玉书,等. 不同植被覆盖下土壤水分遥感监测方法的比较研究 [J]. 中国农学通报, 2014, 30(23): 303-307.

- [15] 刘焕军, 宇万太, 张新乐, 等. 黑土反射光谱特征影响因素分析 [J]. 光谱学与光谱分析, 2009, 29(11): 3019-3022.
- [16] 杨曦光, 于 颖. 基于试验反射光谱数据的土壤含水率遥感反演 [J]. 农业工程学报, 2017, 33(22): 195-199.
- [17] 王 学, 刘全明, 屈忠义, 等. 盐渍化土壤水分微波雷达反演与验证 [J]. 农业工程学报, 2017, 33(11): 108-114.
- [18] 张智韬, 李援农, 杨江涛, 等. 遥感监测土壤含水率模型及精度分析 [J]. 农业工程学报, 2008, 24(8): 152-156.
- [19] 刘全明, 陈亚新, 王耀强, 等. 基于 BP 神经网络技术的土壤水(盐)环境监测 [J]. 内蒙古农业大学学报(自然科学版), 2006, 27(4): 105-109.
- [20] 丁建丽, 陈文倩, 王 璐. HYDRUS 模型与遥感集合卡尔曼滤波同化提高土壤水分监测精度 [J]. 农业工程学报, 2017, 33(14): 166-172.
- [21] 徐 星, 田坤云, 李凤琴, 等. 基于 GA-Elman 神经网络的煤矿突水水源判别 [J]. 西南大学学报(自然科学版), 2018, 40(4): 170-179.

Dynamic Study of Regional Soil Moisture Content Based on Multi-source Remote Sensing Co-inversion

SUN Yu-le, QU Zhong-yi, LIU Quan-ming, WANG Li-ping

College of Water Conservancy and Civil Engineering, Inner Mongolia Agricultural University, Huhhot 010018, China

Abstract: To further promote the application of the multi-source remote-sensing technology on soil moisture monitoring in cropland soils, a study area with 3 500 hectares located at Wuyuan County was used to measure soil moisture and correct multiple remote-sensing images at Hetao Irrigation District, Inner Mongolia, China. The responsive characteristics of soil moisture to the optical image-based surface reflectance and the radar image-based backscatter coefficient were determined. The correlations between remote-sensing image data and soil moisture content were obtained based on the mathematical transformations of remote-sensing image data. Multi-linear regression, least square regression, neural network regression and other regression methods were used to analyze these data with Statistic Package for Social Science (SPSS) and MATLAB. Regression models related to soil moisture content and remote-sensing image data were established for obtaining favorable multi-source image-based soil moisture content inversion models. The neural network regression model of co-retrieval of soil moisture content with ALOS Image, Beijing No. 2 Image and Landsat Image gave a good fitting value (0.892) and a coefficient of determination (R^2) of 0.796. The above results demonstrated that the neural network model integrating multi-source remote-sensing data can quickly and accurately predict the dynamic changes of soil moisture and, thus, provide basic information for agricultural production and management of soil salinization and alkalization.

Key words: remote sensing retrieval; correlation analysis; regression analysis; neural network; moisture inversion model

责任编辑 周仁惠